PATENT ABSTRACTS OF JAPAN

(11)Publication number:

11-045278

(43)Date of publication of application: 16.02.1999

(51)Int.Cl.

G06F 17/30

(21)Application number: 09-217125

(71)Applicant : JUST SYST CORP

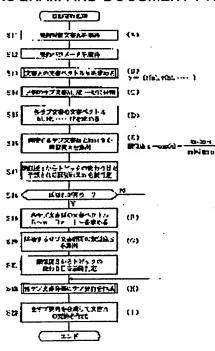
(22)Date of filing:

27.07.1997

(72)Inventor: NOMURA NAOYUKI

FUJISAWA SHINJI

(54) DOCUMENT PROCESSOR, STORAGE MEDIUM STORING DOCUMENT PROCESSING PROGRAM AND DOCUMENT PROCESSING METHOD



(57)Abstract:

PROBLEM TO BE SOLVED: To prepare a summary capable of accurately recognizing contents for respective topics by judging whether or not the plural topics are included in one document.

SOLUTION: The document A is divided into plural sub documents (S14), document vectors (b) for the respective sub documents are obtained (S15) and the similarity degree (s) of the adjacent sub documents with each other is obtained from a cosine value between the adjacent document vectors (b) (S16). A break Xn predicted as the changing point of the topic is temporarily judged from the value of the similarity degree (s) (S17), a document vector B and the similarity degree S for a sub document group for the respective breaks are obtained (S19 and S20) and the changing point of the topic is finally

judged from the similarity degree S (S21). Then, by preparing sub summaries for respective sub document groups finally judged as the changing point of the topic (S22) and synthesizing the sub summaries, the final summary of a summary object document A is attained.

対応なし、英抄

(19)日本国特許庁(JP)

(12) 公開特許公報(A)

(11)特許出願公開番号

特開平11-45278

(43)公開日 平成11年(1999) 2月16日

(51) Int.Cl.⁶

G06F 17/30

識別記号

FΙ

G06F 15/401

3 2 0 Z

15/40

370A

審査請求 未請求 請求項の数15 FD (全 14 頁)

(21)出願番号

特願平9-217125

(71)出願人 390024350

株式会社ジャストシステム

平成9年(1997)7月27日

(72)発明者 野村 直之

徳島県徳島市沖浜東3丁目46番地 株式会

社ジャストシステム内

(72)発明者 藤澤 信二

徳島県徳島市沖浜東3丁目46番地 株式会

社ジャストシステム内

(74)代理人 弁理士 川井 隆 (外1名)

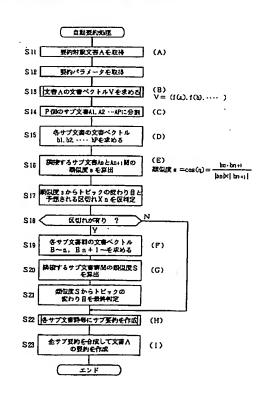
(54) 【発明の名称】 文書処理装置、文書処理プログラムが記憶された記憶媒体、及び文書処理方法

(57)【要約】

【課題】 1文書中に複数のトピックを含むか否か判定し、各トピック毎の内容を的確に把握することが可能な要約を作成する。

【解決手段】 文書Aを複数のサブ文書に分割し(S1

- 4)、各サブ文書毎の文書ベクトルbを求め(S1
- 5)、隣接する文書ベクトルb間でのコサインバリューから隣接するサブ文書同士の類似度sを求める(S1
- 6)。この類似度sの値からトピックの変わり目と予想される区切れXnを仮判定し(S17)、各区切れ毎のサブ文書群に対する文書ベクトルBと類似度Sを求め
- (S19、20)、類似度Sからトピックの変わり目を 最終判定する(S21)。そして、トピックの変わり目 と最終判定した各サブ文書群毎にサブ要約を作成し(S 22)、サブ要約を合成することで要約対象文書Aの最 終的な要約とする。



1

【特許請求の範囲】

【請求項1】 複数の文章で構成された所定形式の文書を取得する文書取得手段と、

前記文書取得手段で取得された文書を複数のサブ文書に分割する文書分割手段と、

前記文書分割手段により分割されたサブ文書間の類似度を算出する類似度算出手段と、

前記類似度算出手段で算出されたサブ文書間の類似度から、前記文書に複数のトピックが含まれるか否かを判定する判定手段と、を備えたことを特徴とする文書処理装 10 置。

【請求項2】 前記文書分割手段で分割されたサブ文書を特徴づける文書ベクトルを決定する文書ベクトル決定手段を備え、

前記類似度算出手段は前記文書ベクトル決定手段で決定 されたサブ文書の文書ベクトルによりサブ文書間の類似 度を算出することを特徴とする請求項1 に文書処理装 置。

【請求項3】 前記判定手段は、前記類似度算出手段で 算出されたサブ文書間の類似度からトピックの変わり目 20 を仮判定し、

前記類似度算出手段は、前記判定手段で仮判定されたトピックの変わり目により再分割したサブ文書群間の類似度を更に算出し、

前記判定手段は、前記類似度算出手段で算出されたサブ 文書群間の類似度から、前記文書に複数のトピックが含 まれるか否かを判定することを特徴とする請求項1又は 請求項2に記載の文書処理装置。

【請求項4】 複数の文書で構成される文書の要約を自動的に作成する要約作成手段を有し、

前記要約作成手段は前記判定手段により前記文書に複数のトピックが含まれると判定された場合、トピックを構成する単位で要約を作成することを特徴とする請求項1、請求項2、又は請求項3に記載の文書処理装置。

【請求項5】 所定のデータと他のデータとの関連付けを行う関連付け手段を有し、

前記関連付け手段は前記判定手段により判定されたトピックを構成する単位で他のデータとの関連付けを行うととを特徴とする請求項1から請求項4のうちのいずれか1の請求項に記載した文書処理装置。

【請求項6】 前記判定手段により複数のトピックスが含まれないと判断された場合。

前記分割手段は、異なるサイズのサブ文書に再分割し、 前記類似度算出手段は、再分割後の隣接サブ文書間の類 似度を再算出し、

前記判定手段は、再算出後の類似度からトピックの変わり目を調べ、前記文書に複数のトピックが含まれるか否かを再判定する、

ことを特徴とする請求項1から請求項5のうちのいずれか1の請求項に記載した文書処理装置。

【請求項7】 複数の文章で構成された所定形式の文書を取得する文書取得機能と、

前記文書取得機能で取得された文書を複数のサブ文書に分割する文書分割機能と、

前記文書分割機能により分割されたサブ文書間の類似度 を算出する類似度算出機能と、

前記類似度算出機能で算出されたサブ文書間の類似度から、前記文書に複数のトピックが含まれるか否かを判定する判定機能と、

.0 をコンピュータに実現させるためのコンピュータ読取り可能な文書処理プログラムが記憶された記憶媒体。

【請求項8】 前記文書分割機能で分割されたサブ文書を特徴づける文書ベクトルを決定する文書ベクトル決定機能を備え

前記類似度算出機能は前記文書ベクトル決定機能で決定 されたサブ文書の文書ベクトルによりサブ文書間の類似 度を算出することを特徴とする請求項7に記載した文書 処理プログラムが記憶された記憶媒体。

【請求項9】 前記判定機能は、前記類似度算出機能で 算出されたサブ文書間の類似度からトピックの変わり目 を仮判定し、

前記類似度算出機能は、前記判定機能で仮判定されたトピックの変わり目により再分割したサブ文書群間の類似度を更に算出し、

前記判定機能は、前記類似度算出機能で算出されたサブ 文書群間の類似度から、前記文書に複数のトピックが含 まれるか否かを判定することを特徴とする請求項7又は 請求項8に記載の文書処理プログラムが記憶された記憶 媒体。

30 【請求項10】 複数の文書で構成される文書の要約を 自動的に作成する要約作成機能を有し、

前記要約作成機能は前記判定機能により前記文書に複数のトピックが含まれると判定された場合、トピックを構成する単位で要約を作成することを特徴とする請求項7、請求項8、又は請求項9に記載の文書処理プログラムが記憶された記憶媒体。

【請求項11】 所定のデータと他のデータとの関連付けを行う関連付け機能を有し、

前記関連付け機能は前記判定機能により判定されたトピ ックを構成する単位で他のデータとの関連付けを行うことを特徴とする請求項7から請求項10のうちのいずれか1の請求項に記載した文書処理プログラムが記憶された記憶媒体。

【請求項12】 前記判定機能により複数のトピックスが含まれないと判断された場合。

前記分割機能は、異なるサイズのサブ文書に再分割し、 前記類似度算出機能は、再分割後の隣接サブ文書間の類 似度を再算出し、

前記判定機能は、再算出後の類似度からトピックの変わ 50 り目を調べ、前記文書に複数のトピックが含まれるか否 かを再判定する、ことを特徴とする請求項7から請求項 11のうちのいずれか1の請求項に記載した文書処理プログラムが記憶された記憶媒体。

【請求項13】 複数の文章で構成された所定形式の文書を取得し、

取得した文書を複数のサブ文書に分割し、

分割したサブ文書間の類似度を算出し、

算出したサブ文書間の類似度から前記文書に複数のトピックが含まれるか否かを判定する、ことを特徴とする文書処理方法。

【請求項14】 隣接するサブ文書間の類似度を、分割したサブ文書を特徴づける文書ベクトルを決定し、決定したサブ文書の文書ベクトルにより算出することを特徴とする請求項13に記載の文書処理方法。

【請求項15】 文書に複数のトピックが含まれると判定された場合、トピックを構成する単位で要約を作成することを特徴とする請求項13または請求項14に記載の文書処理方法。

【発明の詳細な説明】

[0001]

【発明の属する技術分野】との発明は、文書処理装置、 文書処理プログラムが記憶された記憶媒体、及び文書処 理方法に係り、詳細には、作成された文書に複数のトピックが含まれるか否かの判定に関する。

[0002]

【従来の技術】従来、書籍、論文、報告書等の各種の文 書に対し、要約(抄録を含む)の自動作成処理や、他文 書等との関連づけ処理等の各種処理をコンピュータを用 いて行うことが行われている。文書の自動要約について は、例えば、「全文情報からの意味的情報の抽出と加 工」(情報処理学会第38回全国大会予稿集、第222 頁;1989年)で提案されている。この方法では、ま ず文書中の重要語を字種や動詞等の情報から抽出し、さ らに重要語の出現頻度から最重要語を決定する。次に重 要語と最重要語が出現するか否かから重要文を決定する ことで、自動的に要約を作成することが可能になる。ま た、文章の段落の性質を反映させることで、より正確に 要約を作成する特開平3-191475号公報に記載さ れた方法等も提案されている。一方、他のデータとの関 連づけとしては、インターネットにおけるハイパーリン 40 クや、フレームシステム等による知識処理(エキスパー トシステム等) における関連づけ等が行われている。 [0003]

【発明が解決しようとする課題】しかし、従来の文書処理では、処理対象となっている文書中に複数のトピック る。請求項4に記載した発明では、図13に示す1例の (論題)が含まれているか否かを判定することはできず、全体として文書を処理していた。このため、上記した従来の自動要約の方法の場合、単一のトピックが含まれている文書に対しては比較的適切な要約を作成すると表が可能であるが、1文書中に複数のトピックを含む文 50 文書に複数のトピックが含まれると判定された場合、ト

書に対しては必ずしも適切な要約を作成することができなかった。すなわち、互いに異なる主張や事実の記載をもつ複数ユニットの存在を無視して重要文の文選択を行い、互いにつなぎ合わせることで要約を作成していたため、可読性の低い要約を生成していた。また、複数のトピックを含む文書であっても文書全体に対してしか関連づけることができなかった。

【0004】本発明は、このような従来の課題を解決するために成されたもので、1文書中に複数のトピックを含むか否か判定することができる文書処理装置を提供することを第1の目的とする。また、本発明は、1文書中に複数のトピックを含むか否かを判定することができるコンピュータ読取り可能な文書処理プログラムが記憶された記憶媒体を提供することを第2の目的とする。また、本発明は、1文書中に複数のトピックを含むか否かを判定することができる文書処理方法を提供することを第3の目的とする。

[0005]

【課題を解決するための手段】請求項1記載の発明で 20 は、図11に示すように、複数の文章で構成された所定 形式の文書を取得する文書取得手段101と、前記文書 取得手段101で取得された文書を複数のサブ文書に分 割する文書分割手段102と、前記文書分割手段102 により分割されたサブ文書間の類似度を算出する類似度 算出手段103と、前記類似度算出手段103で算出さ れたサブ文書間の類似度から前記文書に複数のトピック が含まれるか否かを判定する判定手段104と、を文書 処理装置に備えさせて前記第1の目的を達成する。 請求 項2に記載した発明では、図12に示すように、請求項 1に記載した文書処理装置において、前記文書分割手段 102で分割されたサブ文書を特徴づける文書ベクトル を決定する文書ベクトル決定手段105を備え、前記類 似度算出手段103は前記文書ベクトル決定手段105 で決定されたサブ文書の文書ベクトルによりサブ文書間 の類似度を算出する。請求項3に記載した発明では、図 11、図12に示されるように、請求項1又は請求項2 に記載した文書処理装置において、前記判定手段104 は、前記類似度算出手段103で算出されたサブ文書間 の類似度からトピックの変わり目を仮判定し、前記類似 度算出手段103は、前記判定手段104で仮判定され たトピックの変わり目により再分割したサブ文書群間の 類似度を更に算出し、前記判定手段104は、前記類似 度算出手段103で算出されたサブ文書群間の類似度か ら前記文書に複数のトピックが含まれるか否かを判定す る。 請求項4 に記載した発明では、図13 に示す1例の ように、請求項1、請求項2、又は請求項3に記載した 文書処理装置において、複数の文書で構成される文書の 要約を自動的に作成する要約作成手段106を有し、前 記要約作成手段106は前記判定手段104により前記

ピックを構成する単位で要約を作成する。 請求項5 に記 載した発明では、図14に示す1例のように、請求項1 から請求項4のうちのいずれか1の請求項に記載した文 書処理装置において、所定のデータと他のデータとの関 連付けを行う関連付け手段107を有し、前記関連付け 手段107は前記判定手段104により判定されたトピ ックを構成する単位で他のデータとの関連付けを行う。 請求項6に記載した発明では、図11から図14に示す 1例のように、請求項1から請求項5のうちのいずれか 1の請求項に記載した文書処理装置において、前記判定 10 手段により複数のトピックスが含まれないと判断された 場合、前記分割手段は、異なるサイズのサブ文書に再分 割し、前記類似度算出手段は、再分割後のサブ文書間の 類似度を再算出し、前記判定手段は、再算出後の類似度 から前記文書に複数のトピックが含まれるか否かを再判 定する。請求項7に記載した発明では、図15に示すよ うに、複数の文章で構成された所定形式の文書を取得す る文書取得機能201と、前記文書取得機能201で取 得された文書を複数のサブ文書に分割する文書分割機能 202と、前記文書分割機能202により分割されたサ 20 ブ文書間の類似度を算出する類似度算出機能203と、 前記類似度算出機能203で算出されたサブ文書間の類 似度から前記文書に複数のトピックが含まれるか否かを 判定する判定機能204と、をコンピュータに実現させ るためのコンピュータ読取り可能な文書処理プログラム を記憶媒体に記憶させて前記第2の目的を達成する。請 求項8に記載した発明では、図16に示すように、請求 項7 に記載した記憶媒体において、前記文書分割機能2 02で分割されたサブ文書を特徴づける文書ベクトルを 決定する文書ベクトル決定機能205を備え、前記類似 30 度算出機能203は前記文書ベクトル決定機能205で 決定されたサブ文書の文書ベクトルにより隣接する2つ のサブ文書間の類似度を算出する。請求項9に記載した 発明では、図15、図16に示すように、請求項7又は 請求項8に記載した記憶媒体において、前記判定機能2 04は、前記類似度算出機203能で算出されたサブ文 書間の類似度からトピックの変わり目を仮判定し、前記 類似度算出機能203は、前記判定機能204で仮判定 されたトピックの変わり目により再分割したサブ文書群 間の類似度を更に算出し、前記判定機能204は、前記 類似度算出機能203で算出されたサブ文書群間の類似 度から前記文書に複数のトピックが含まれるか否かを判 定する。請求項10に記載した発明では、図17に示す 1例のように、請求項7、請求項8、又は請求項9に記 載した記憶媒体において、複数の文書で構成される文書 の要約を自動的に作成する要約作成機能206を有し、 前記要約作成機能206は前記判定機能204により前 記文書に複数のトピックが含まれると判定された場合、 トピックを構成する単位で要約を作成する。請求項11 に記載した発明では、図18に示す1例のように、、請 50

求項7から請求項10のうちのいずれか1の請求項に記 載した記憶媒体において、所定のデータと他のデータと の関連付けを行う関連付け機能207を有し、前記関連 付け機能207は前記判定機能204により判定された トピックを構成する単位で他のデータとの関連付けを行 う。請求項12に記載した発明では、図15から図18 に示す1例のように、請求項7から請求項11のうちの いずれか1の請求項に記載した記憶媒体において、前記 判定機能204により複数のトピックスが含まれないと 判断された場合、前記分割機能202は、異なるサイズ のサブ文書に再分割し、前記類似度算出機能203は、 再分割後のサブ文書間の類似度を再算出し、前記判定機 能204は、再算出後の類似度から前記文書に複数のト ビックが含まれるか否かを再判定する。請求項13に記 載した発明では、図19に示すように、複数の文章で構 成された所定形式の文書を取得301し、取得した文書 を複数のサブ文書に分割302し、分割したサブ文書間 の類似度を算出303し、算出したサブ文書間の類似度 から前記文書に複数のトピックが含まれるか否かを判定 304する、ことにより前記第3の目的を達成する。請 求項14に記載した発明では、図20に示すように、請 求項13に記載した文書処理方法において、隣接するサ ブ文書間の類似度を、分割したサブ文書を特徴づける文 書ベクトルを決定303aし、決定したサブ文書の文書 ベクトルにより算出303bする。請求項15に記載し た発明では、図21に示す1例のように、請求項13ま たは請求項14に記載した発明において、文書に複数の トピックが含まれると判定された場合、トピックを構成 する単位で要約305を作成する。

[0006]

【発明の実施の形態】以下、本発明の文書処理装置、文書処理プログラムが記憶された記憶媒体、及び文書処理方法における好適な実施の形態について、図1から図10を参照して詳細に説明する。

(1) 実施形態の概要

本実施形態では、文書を複数のサブ文書(ユニット)に分割し、各サブ文書毎の文書ベクトルを求め、サブ文書間もしくは、複数のサブ文書のセット間で文書ベクトルの差をとる。これらの連続する2つのサブ文書間のコサインバリュー(cosine value)が著しく低い箇所で再分割を行う。その再分割位置の前mユニット、後nュニットの間の全体的な類似性の判定も行い、それが所定の関値T2以下になった際にトピックの変わり目と最終判定する。そして、単一のトピックの領域毎に従来の要約処理を適用することにより、1つの要約でなく、一種の複数の要約の集まりとして文書全体の要約を生成する。なお、各トピック毎の要約結合の際に、各トピックとされた複合名詞句をサマリー中のサブセクションのタイトルとして明示するようにしてもよい。

【0007】(2)実施形態の詳細

図1は、文書処理装置の構成を表したブロック図であ る。本実施形態の文書処理装置は、バーソナルコンピュ ータやワードプロセッサ等を含むコンピュータシステム として構成し、また、LAN(ローカル・エリア・ネッ トワーク)のサーバやインターネットを含むコンピュー タ(パソコン)通信のホストとして構成することが可能 である。文書処理装置は、図1に示すように装置全体を 制御するための制御部11を備えている。この制御部1 1には、データバス等のバスライン21を介して、入力 装置としてのキーボード12やマウス13、表示装置1 4、印刷装置15、記憶装置16、記憶媒体駆動装置1 7、通信制御装置18、入出力1/F19、および、文 字認識装置20が接続されている。制御部11は、CP U111、ROM112、RAM113を備えている。 ROMII2は、CPUIIIが各種制御や演算を行う ための各種プログラムやデータが予め格納されたリード オンリーメモリである。

[0008] RAM113は、CPU111にワーキン グメモリとして使用されるランダムアクセスメモリであ る。 とのRAM113には、本実施形態による要約処理 20 を行うためのエリアとして、要約対象文書格納エリア1 131、要約パラメータ格納エリア1132、区切れ位 置格納エリア1133こ文書ベクトル格納エリア113 4、要約格納エリア1135、その他の各種エリアが確 保されるようになっている。文書ベクトル格納エリア1 134には、要約対象文書に対する文書ベクトルと、後 述する各サブ文書に対する文書ベクトルとが格納され る。要約格納エリア1135には、本実施形態により発 見された各トピックを含む各サブ文書群に対するサブ要 約と、要約対象文書全体に対する要約とが格納される。 【0009】キーボード12は、かな文字を入力するた めのかなキーやテンキー、各種機能を実行するための機 能キー、カーソルキー、等の各種キーが配置されてい る。マウス13は、ポインティングデバイスであり、表 示装置14に表示されたキーやアイコン等を左クリック することで対応する機能の指定を行う入力装置である。 表示装置14は、例えばCRTや液晶ディスプレイ等が 使用される。との表示装置には、要約対象文書の内容 や、本実施形態により自動生成された要約の内容等が表 示されるようになっている。印刷装置15は、表示装置 40 14に表示された文章や、記憶装置16の文書格納部1 64 に格納された文書等の印刷を行うためのものであ る。この印刷装置としては、レーザプリンタ、ドットプ リンタ、インクジェットプリンタ、ページプリンタ、感 熱式プリンタ、熱転写式プリンタ、等の各種印刷装置が 使用される。

【0010】記憶装置16は、読み書き可能な記憶媒体 と、その記憶媒体に対してプログラムやデータ等の各種 情報を読み書きするための駆動装置で構成されている。 この記憶装置16に使用される記憶媒体としては、主と 50 【0013】例えば図2おいて、文書Bのキーワードは

してハードディスクが使用されるが、後述の17で使用 される各種記憶媒体のうちの読み書き可能な記憶媒体を 使用するようにしてもよい。記憶装置16は、仮名漢字 変換辞書161、プログラム格納部162、データ格納 部163、文書データベース164、要約データベース 165、文書ベクトルデータベース166、図示しない その他の格納部(例えば、との記憶装置16内に格納さ れているプログラムやデータ等をバックアップするため の格納部) 等を有している。プログラム格納部162に は、本実施形態における自動要約処理プログラム、文書 ベクトル作成処理プログラム、要約作成処理プログラム 等の各種プログラムの他、仮名漢字変換辞書 161を使 用して入力された仮名文字列を漢字混り文に変換する仮 名漢字変換プログラム等の各種プログラムが格納されて いる。データ格納部163には、要約パラメータのデフ ォルト値等の各種データが格納されている。要約パラメ ータのデフォルト値としては、例えば、全文書に対する 要約の比率=「25%」や、日付時刻、価格情報、物理 量(サイズ、重量、温度等)等の数量重視=「しない」 や、URL (Uniform Resource Locator) 重視=「しな・ い」、長単文の重視=「しない」や、です/ます/であ るの選択=「しない」、等の値が格納されている。 【0011】文書データベース164には、仮名漢字変

換プログラムにより作成された文書や、他の装置で作成 されて記憶媒体駆動装置17や通信制御装置18から読 み込まれた文書が格納される。この文書データベース1 64 に格納される各文書の形式は特に限定されるもので はなく、テキスト形式の文書、HTML (Hyper TextMa rkup Language) 形式の文書、JIS形式の文書等の各 種形式の文書の格納が可能である。文書データベース 1 64には、これらの形式の文書データの他、本実施形態 により発見されたトピックの変わり目となる区切れ位置 Xのデータ等も格納される。要約データベース165、 及び文書ベクトルデータベース166には、文書データ ベース 1 6 4 に格納されている各文書に対応する要約や 文書ベクトルが格納されるようになっている。

【0012】図2は、文書ベクトルデータベース166 の内容を概念的に表したものである。との図2に示され るように、文書中から自動抽出されたキーワードxに対 して求められた重要度 f (x)が文書ベクトルの要素値 f(x)として格納されている。この文書ベクトルは各 文書(A、B、C…)毎に格納され、文書データベース 164に格納されている各文書と対応づけられている。 各文書ベクトルの次元は採用するキーワード x (重要語 句)の数であるが、2文書間の類似度を両文書ベクトル から求める場合には、両文書のキーワードの和集合の数 が両文書ベクトルの次元となる。この場合、一方の文書 ベクトルにのみ含まれるキーワードに対する他方の文書 ベクトルの要素値は、"0"に定義される。

(6)

「重要、重要語、重要度、…」、文書Cのキーワードは 「重要、…、政治、…」であり、両文書の文書ベクトル は次の通りである。

文書Bの文書ベクトル= (1,18,19,…) 文書Cの文書ベクトル= (18,…,21,…) これに対して文書Bと文書Cとの類似度を算出する場合 には、両文書のキーワードを「重要、重要語、重要度、 …、政治、…」とし、両文書の文書ベクトルはつぎの通 り定義される。

文書Aの文書ベクトル= (1, 18, 19, …, 0, …)、

文書Cの文書ベクトル=(18, 0, 0, …, 2 1, …)

【0014】記憶媒体駆動装置17は、CPU111か 外部の記憶媒体からコンピュータプログラムや文書を含 むデータ等を読み込むための駆動装置である。記憶媒体 に記憶されているコンピュータプログラム等には、本実 施形態の文書処理装置により実行される各種処理のため のプログラム、および、そとで使用される辞書、データ 等も含まれる。ことで、記憶媒体とは、コンピュータブ 20 ログラムやデータ等が記憶される記憶媒体をいい、具体 的には、フロッピーディスク、ハードディスク、磁気テ ープ等の磁気記憶媒体、メモリチップやICカード等の 半導体記憶媒体、CD-ROMやMO、PD(相変化書) 換型光ディスク)等の光学的に情報が読み取られる記憶 媒体、紙カードや紙テープ等の用紙(および、用紙に相 当する機能を持った媒体)を用いた記憶媒体、その他各 種方法でコンピュータプログラム等が記憶される記憶媒 体が含まれる。本実施形態の文書処理装置において使用 される記憶媒体としては、主として、CD-ROMやフ ロッピーディスク等の記憶媒体がが使用される。記憶媒 体駆動装置17は、これらの各種記憶媒体からコンピュ ータプログラムを読み込む他に、フロッピーディスクの ような書き込み可能な記憶媒体に対してRAM113や 記憶装置16に格納されているデータ等を書き込むこと が可能である。

【0015】本実施形態の文書処理装置では、制御部11のCPU111が、記憶媒体駆動装置17にセットされた外部の記憶媒体からコンピュータプログラムを読み込んで、記憶装置16の各部に格納(インストール)す 40る。そして、本実施形態による自動要約処理等の各種処理を実行する場合、記憶装置16から該当プログラムをRAM113に読み込み、実行するようになっている。但し、記憶装置16からではなく、記憶媒体駆動装置17により外部の記憶媒体から直接RAM113にプログラムを読み込んで実行することも可能である。また、文書処理装置によっては、本実施形態の自動要約処理プログラム等を予めROM112に記憶させておき、これをCPU111が実行するようにしてもよい。さらに、本実施形態の自動要約処理プログラム等の各種プログラム 50

やデータを、通信制御装置18を介して他の記憶媒体からダウンロードし、実行するようにしてもよい。

【0016】通信制御装置18は、他のパーソナルコンピュータやワードプロセッサ等との間でテキスト形式やHTML形式等の各種形式の文書やビットマップデータ等の各種データの送受信を行うことができるようになっている。入出力I/F19は、音声や音楽等の出力を行うスピーカ等の各種機器を接続するためのインターフェースである。文字認識装置20は、用紙等に記載された10 文字をテキスト形式やHTML等の各種形式で認識する装置であり、イメージスキャナや文字認識プログラム等で構成されている。

【0017】本実施形態では、キーボード12の入力操作により作成した文書(RAM113の所定格納エリアに格納)の他、外部で作成して所定の記憶媒体に格納した文書で記憶媒体駆動装置17から読み込んだ文書、予め文書データベースに格納されている文書、通信制御装置18からダウンロードした文書、及び文字認識装置20で文字認識した文書、等の各種文書を対象文書として取得する(文書取得手段)ことが可能である。

【0018】以上のように構成された本実施形態の文書 処理装置による、トピック数に応じた要約を作成する自 動要約処理の動作について図3から図10を用いて説明 する。図3は自動要約処理のメイン動作を表したもので あり、図4~図8は自動要約処理の各工程における処理 を概念的に表したものである。この図3のフローチャー トの右側に記した(A)~(I)は図4から図8の (A)~(I)に対応したものである。図4(A)~図 8(1)中に示した文書ベクトルは、概念的に理解しや 30 すくするために2次元で表示したものであるが、実際に はN次元ベクトルである。CPU1111は、要約を作成 する対象となっている要約対象文書A (図4 (A))を 取得し、RAM113の要約対象文書格納エリア113 1に格納する(ステップ11)。要約対象文書Aは、ユ ーザの指示に従ってRAM113(自装置内で作成され た文書である場合)、記憶装置16の文書データベース 164 (要約が未だ作成されていない文書である場 合)、記憶媒体駆動装置17(自装置または他装置で作 成済みの文書の場合)、通信制御装置18 (パソコン通 信、インターネット等の通信による場合) から取得す

【0019】次にCPU111は、ユーザによってキーボード12等から要約バラメータが入力された場合には入力値を取得し、ユーザによる入力がない場合にはデータ格納部163に格納された要約バラメータのデフォルト値を取得し、要約バラメータ格納エリア1132に格納する(ステップ12)。

る。

クラム等を予めROM112に記憶させておき、これを 【0020】次にCPU111は、要約対象文書格納エ CPU111が実行するようにしてもよい。さらに、本 リア1131に格納した要約対象文書Aに対する文書べ 実施形態の自動要約処理プログラム等の各種プログラム 50 クトルV(図4(B))を求める(ステップ13)。図

9は、文書ベクトル作成処理の動作を表したフローチャ ートである。CPU111は、形態素解析を行うことで 要約対象文書Aから自立語を抽出する(ステップ13

1)と共に、名詞句、複合名詞句等を含めた候補語

(句)を要約対象文書Aから抽出しRAM113の所定 作業領域に格納する(ステップ132)。そして抽出し た候補語(句)の要約対象文書Aでの出現頻度、評価関 数から、各候補語(句)の重要度f(x)を決定する (ステップ133)。 ことで、評価関数としては、例え 要語に対する重み付け、単語、名詞句、複合名詞句等の 候補語(句)の種類による重み付け等が使用される。さ らにCPU111は、決定した重要度f(x)の値から 要約対象文書Aのキーワードa.b.…を決定する(ス テップ134)。そして、各キーワードの重要度f (x)を要素として、文書ベクトルV = (f(a), f

(b), …)をRAM113の文書ベクトル格納エリア 1134に格納して(ステップ135)、図3の自動要 約処理ルーチンにリターンする。

【0021】文書ベクトルVが求まるとCPU111 は、図5 (C) に示すように要約対象文書Aを所定数の P個のサブ文書A1, A2, …, APに分割する。サブ 文書の分割方法は任意であり、具体的には、r文字数毎 に分割、s 行数毎に分割、t ページ毎に分割、u センテ ンス毎に分割、全文字数を1/Rに分割、全行数を1/ Sに分割、全ページを1/Tに分割、全センテンスを1 /Uに分割、等の方法がある。また、サブ文書サイズを*

類似度snn+l=COS(a)

 $= (bn \cdot bn + 1) / (|bn| \times |bn + 1|)$

【数1】

[0023]

をとり、1に近いほど2つの文書ベクトルが互いに平行 に近く、2つのサブ文書同士は似ていると考えることが

【0025】次にCPU111は、算出した類似度sn n+1からトピックの変わり目であると予想される区切 れXnを仮判定する。すなわち、各類似度snn+1と 所定の閾値T1とを比較し、閾値T1以下の類似度sn n+ に対応する区切りXnをトピックの区切れと仮判 定する(ステップ17)。 CCで、CPU1111は、類 し(ステップ18)、ない場合には(ステップ18; N)、文書A全体をサブ文書としてステップ22に移行 する。一方、類似度 s が閾値T 1 以下の区切れX n が有 る場合(ステップ17;Y)、その区切れXnまでのサ ブ文書群(サブ文書A1からAnまで)と、区切れ以降 のサブ文書群(サブ文書An+1からAPまで)の文書 ベクトルB \sim n、Bn+l \sim を、図6(F)に示すよう に、図9に従って説明した文書ベクトル作成処理により 求める(ステップ19)。なお、類似度 s から求まる区 切れが複数(m個)ある場合には、各区切れ単位の各サ 50 プ22)。図10は、要約作成処理の動作を表したフロ

*一定サイズで分割せず、文書中の一部(例えば、文書 頭、文書中央、文書末等)を他の部分よりも大きなサイ ズのサブ文書とすることも可能である。これらの分割方 法は、いずれか1の方法が予め規定され、または、ユー ザにより要約パラメータの1つとして選択可能にしても よい。CPU1111は、分割による切れ目がセンテンス の途中になる場合には、そのセンテンス全体が前のサブ 文書に含まれる位置をサブ文書の区切れ位置Xとして各 サブ文書の区切れ位置Xn(n=1~(P-1))を求 ば、所定の重要語が予め指定されている場合にはその重 10 め、区切れ位置格納エリア1133に格納する(ステッ プ14)。

> 【0022】次にCPU111は、図9に従って説明し た文書ベクトル作成処理により、区切れ位置Xで区切ら れた各サブ文書A1~APをそれぞれ1つの文書とみな して文書ベクトルb1~bP(図5(D))を求める (ステップ15)。そして、図6(E)に示すように、 互いに隣接するサブ文書AnとAn+1(n=1~P-1) との間の類似度 s n n + 1 を、両者の文書ベクトル bnと文書ベクトルbn+1間の角度に依存するコサイ 20 ンにより求める(ステップ16)。すなわち、両文書べ クトルbnとbn+1間の角度をqとし、両文書ベクト ルの内積をbn・bn+1とし、両文書ベクトルの大き さをそれぞれ | bn |、 | bn + 1 | とした場合、両文 書ベクトルの類似度 s n n + 1 は次の数式 1 により求ま る。

【0024】この類似度sの値は $-1 \le s \le 1$ までの値 30 ブ文書群m+1個に対して文書ベクトルを作成するが、 本実施形態では、説明を簡単にするため区切れは1つで あった場合を例に説明する。

【0026】次にCPU111は、ステップ16と同様 に、前記した数式1に従って隣接するサブ文書群間の類 似度Sを算出する(ステップ20、図7(G))。そし て、類似度Sが所定の閾値T2よりも大きい場合、ステ ップ17で仮判定した区切れXnは細かなサブ文書に分 割したためにたまたま隣接するサブ文書An、An+1 の両文書ベクトルbnとbn+tとが離れたものと判断 似度 s が関値T 1 以下の区切れX C が有るか否かを判断 40 できるので、区切れX n はトピックの変わり目ではない と判断する。一方、類似度Sが所定の閾値T2以下であ れば、サブ文書群(Al~An)とサブ文書群(An+ 1~AP) は異なる内容について記載されており互いに 似ていないと判断できるので、区切れXnはトピックの 変わり目であると最終判定し、RAM113の区切れ位 置格納エリア1133に格納する(ステップ21)。 【0027】次にCPU111は、図7 (H) に示すよ うに、異なるトピックを含む各サブ文書群(Al~A n、An+1~AP)毎にサブ要約を作成する(ステッ

13

ーチャートである。CPU111は、まず形態素解析を行うことでサブ文書群に含まれる自立語を抽出する(ステップ221)と共に、名詞句、複合名詞句等を含めた候補語(句)を要約対象文書Aから抽出しRAM113の所定作業領域に格納する(ステップ222)。そして、RAM16の要約パラメータ格納エリア1132に格納した要約パラメータや、抽出した候補語(句)のサブ文書群中での出現頻度、評価関数等から、各候補語(句)重要度f(y)を決定する(ステップ223)。ここで、評価関数としては、例えば、所定の重要語が予りが指定されている場合にはその重要語に対する重み付け、単語、名詞句、複合名詞句等の候補語(句)の種類による重み付け等が使用される。

【0028】さらにCPU111は、決定した重要度 f (y)や要約パラメータ格納エリアリレーに格納された 要約パラメータ等から、サブ文書群含まれる各センテンスに対する重要度F(z)を決定する(ステップ224)。そして、決定したセンテンスの重要度F(z)の 重要度が高いセンテンスの上位から要約パラメータの要約比率(例えば、サブ文書群の全センテンス数の内の上20位25%)以内に入るセンテンスをリストアップする(ステップ225)。そしてCPU111は、リストアップしたセンテンスをサブ文書群の中での出現順に並べることで当該サブ文書群についてのサブ要約とし、これをRAM113の要約格納エリアに格納して(ステップ226)、図3の自動要約処理ルーチンにリターンする。

【0029】各サブ文書群に対するサブ要約の作成が終了するとCPU111は、図8(I)に示すように、要約格納エリアに格納した全てのサブ要約を合成することで要約対象文書Aについての要約とし、要約格納エリア1136の所定エリアに格納して(ステップ23)、本実施形態による自動要約処理を終了する。以上説明したように、本実施形態による自動要約処理によれば、1文書中に複数のトピックを含むか否かを判定し、各トピック毎のサブ要約を合成して要約を作成しているので、各トピックの内容を的確に把握することが可能な要約を作成することができる。

【0030】以上の自動要約処理が終了すると、CPU 111はユーザの指示によりRAM113に格納した各 40 データの保存処理を行う。すなわち、要約対象文書格納エリア1131から要約対象文書Aを読み出して、記憶装置16の文書データベース164に格納する。また作成した要約を要約格納エリア1135から読み出し、文書データベース164に格納した要約対象文書Aとの関連性を付けて記憶装置16の要約データベース165に格納する。さらに、文書ベクトル作成処理(図3のステップ13、図9)で求めた文書ベクトルVを文書ベクトル格納エリア1135から読み出し、文書データベース 164に格納した要約対象文書Aとの関連性を付けて記 50

憶装置16の文書ベクトルデータベース166に格納する。

【0031】以上、本実施形態の構成および自動要約処理について説明したが、本発明では、これらの各形態に限定されるものではなく、各請求項に記載された発明の範囲内で種々の変形をすることが可能である。例えば実施形態では、形態素解析及び候補語(句)の抽出について、文書ベクトル作成処理(図9のステップ131とステップ132)と、要約作成処理(図10のステップ221とステップ222)とにおいて独立して同様な処理を行うこととしたが、本発明では、文書ベクトル作成処理で抽出した候補語(句)をRAM16の所定エリアに格納しておき、要約作成処理で利用するようにしてもよい。

【0032】また説明した実施形態では、自動要約処理 が終了した後の保存処理において、要約対象文書A、要 約、文書ベクトルVのみを記憶装置16の各データベー ス164、165、166に格納し保存するようにした が、本発明では更に、文書ベクトル作成処理(図9)の ステップ132で要約対象文書Aから抽出し、RAM1 13の所定作業領域に格納した候補語(句)を要約対象 文書Aと関連つけて、文書データベース164、又は専 用の候補語(句)データベースに格納するようにしても よい。また要約パラメータ格納エリア1132から要約 パラメータを読み出して、当該要約に関連付けて、要約 データベース166、または専用の要約パラメータデー タベースに格納するようにしてもよい。また、ステップ 20(図3)において最終的にトピックの変わり目であ ると判定した区切れXnを区切れ位置格納エリア113 3から読み出し、要約対象文書Aと関連つけて、文書デ ータベース164、又は専用のトピック区切れデータベ ースに格納するようにしてもよい。

【0033】さらに、説明した実施形態では、文書ベクトル作成処理(ステップ13、図9)及び要約作成処理(ステップ22、図10)の両処理において、形態素解析(ステップ131、221)と候補語(句)の抽出(ステップ132、222)を行った。しかし、同一センテンスに対する処理であるため、抽出した候補語(句)は同一である。そこで、本発明では、文書ベクトル作成処理で抽出した候補語(句)をRAM113の所定エリアに格納しておき、要約処理において格納した候

定エリアに格納しておき、要約処理において格納した候補語(句)を使用することでステップ221とステップ222を省略するようにしてもよい。この候補語(句)についても、要約対象文書Aに対する候補語(句)として文書データベース164、又は専用の候補語(句)データベースに格納するようにしてもよい。

【0034】また、説明した実施形態ではトピックの変わり目を判定する関値T1、T2として予め決められた固定値を使用するようにしたが、本発明では関値の値をユーザが変更することができるようにしてもよい。ま

30

た、予想トピック数u(固定値の閾値関数や過去の類似 文書における履歴から算出)をパラメータに取り入れた 閾値関数T1(u)、T2(u)を使用するようにして もよい。

15

【0035】また説明した実施形態では、要約対象文書 AをP個のサブ文書に分割し、トピックの変わり目と予 想される区切れXnの仮判定刷を1回だけ行い、句切れ がない場合(ステップ18;N)にはトピックが複数存 在しないと判断して要約対象文書Aに全体に対する要約 を作成する場合について説明した。しかし、あるサブ文 10 書Anの中央に実際のトピックの変わり目が存在した場 合、そのサブ文書の文書ベクトルbnが中間的な値とな り、隣接サブ文書bn-l、bn+lとの間で有為な差 が出ない、すなわち、隣接する前後のサブ文書との類似 度sn-ln、snn+lが閾値Tl以下にならない可 能性がある。そこで、ステップ18において句切れがな いと判断された場合(ステップ18;N)、サブ文書に 分割するサイズを乱数や、互いに素な数値(例えば、5 に対して10にするのでなく4か6にするとの意味)で のを採用するようにしてもよい。

【0036】説明した実施形態では、要約対象文書Aに 複数のトピックが含まれてるか否かを判定し、その結果 を要約の作成処理に適用する場合について説明したが、 本発明ではトピックの判定結果を他に適用するようにし てもよい。例えば、WEBのSOMLにおいてリンクを張る 場合、判定したトピック単位で特定のポインタを指すよ うにしてもよい。また、ハイパーリンクの飛び先を判定 したトピック単位とし、ファイングレインドで指定する ようにしてもよい。

【0037】説明した実施形態では文書ベクトルを作成 する方法として図9のフローチャートに従った方法を1 例にして説明したが、本発明でこの方法に限られるもの ではなく、要約対象文書中Aからキーワードを抽出する 方法や、抽出キーワードに対する重要度(=文書ベクト ルの要素値)の決定方法等については、公知の各種方法 により置き換えることが可能である。また、各サブ文書 群に対する要約の作成処理についても同様に図10のフ ローチャートに示した方法に限られるものではなく、公 知の各種要約方法、抄録作成方法等を資料することが可 40 もより精度の高い複数トピック検索を行うことができ 能である。更に、2つの文書ベクトルの類似度の算出方 法については、数式1により類似度を算出することとし たが、この数式に限定されるものではなく、ベクトル相 互間の類似関係を表すことが可能であれば他の数式によ り類似度を算出することも可能である。

【0038】説明した実施形態は日本語で作成された文 **書に限られるものではなく、あらゆる言語で作成された** 文書を対象とすることが可能である。その場合、対象と なる文書が作成された言語用の形態素解析アルゴリズム 等を使用するといった、本発明の構成には影響のない部 50 分を変更するだけでよい。

【0039】以上の実施形態において説明した、各装 置、各部、各動作、各処理等に対しては、それらを含む 上位概念としての各手段(~手段)により、実施形態を 構成することが可能である。例えば、「類似度s が閾値 T1以下の区切れXCが有るか否かを判断し (ステップ 18)」との記載に対して「区切れ有無判断手段」を構 成し、「決定した重要度f(x)の値から要約対象文書 Aのキーワードa, b, …を決定する(ステップ13 4)」との記載に対して「キーワード決定手段」を構成 し、「決定したセンテンスの重要度F(z)の重要度が 高いセンテンスの上位から要約パラメータの要約比率 (例えば、サブ文書群の全センテンス数の内の上位25 %) 以内に入るセンテンスをリストアップする (ステッ プ225)」との記載に対して「センテンスリストアッ ブ手段」を構成するようにしてもよい。同様に、その他 各種動作に対して「~ (動作)手段」等の上位概念で実 施形態を構成するようにしてもよい。

16

【0040】また第1変形として、図11に示すよう 少し変化させ、複数回リトライして有為な差が生じたも 20 に、複数の文章で構成された所定形式の文書を取得する 文書取得手段101と、前記文書取得手段101で取得 された文書を複数のサブ文書に分割する文書分割手段1 02と、前記文書分割手段102により分割された各サ ブ文書について、隣接する2つのサブ文書間の類似度を 算出する類似度算出手段103と、前記類似度算出手段 103で算出された各サブ文書間の類似度からトピック の変わり目を調べ、前記文書に複数のトピックが含まれ るか否かを判定する判定手段104と、を文書処理装置 に備えさせて前記第1の目的を達成するようにしてもよ い。第2変形として、図12に示すように、第1変形に 記載した文書処理装置において、前記文書分割手段10 2で分割されたサブ文書を特徴づける文書ベクトルを決 定する文書ベクトル決定手段105を備え、前記類似度 算出手段103は前記文書ベクトル決定手段105で決 定された各サブ文書の文書ベクトルにより隣接する2つ のサブ文書間の類似度を算出する。このように、隣接す る2つのサブ文書間での類似度を算出することで、CP U111による処理量(計算量)を減らすことだでき、 また、1文書におけるテキストの連続性(連結性)から る。

> 【0041】ただし、本発明では、必ずしも隣接する2 つのサブ文書間での類似度を算出する必要はなく、例え ば、隣接する3つ以上のサブ文書間の類似度を算出する ようにしてもよい。すなわち、注目のサブ文書と、その 前後のサブ文書とで比較を行い、その結果を(同時に) 勘案して、トピックの変わり目が、1)注目サブ文書の 中か、2) その直後のサブ文書境界か、3) その直前の サブ文書境界か、のいずれであるかを一時に判定する、

ようにしてもよい。また必ずしも隣接しないサブ文書間

での類似度を判定するようにしてもよい。この場合に は、段落間の1、2個の改行コード、空白コードを処理 上は、サブ文書とし、この改行等によるサブ文書を飛び 越えたサブ文書間の類似度を算出する場合も含まれる。 [0042]

【発明の効果】本発明によれば、複数の文章で構成され た所定形式の文書を取得し、取得した文書を複数のサブ 文書に分割し、分割した各サブ文書について、隣接する 2つのサブ文書間の類似度を算出し、算出した各サブ文 書間の類似度からトピックの変わり目を調べ、文書に複 10 数のトピックが含まれるか否かを判定するようにしたの で、自動的に複数のトピックが含まれているか否かを判 断することができる。従って、各トピック毎の要約を作 成したり、各トピック毎に他の文書やデータ間での関連 付けを行うことができる。

【図面の簡単な説明】

- 【図1】本発明の1実施形態における文書処理装置の構 成を表したブロック図である。
- 【図2】同上、実施形態における文書ベクトルデータベ ースの内容を概念的に表した説明図である。
- 【図3】同上、実施形態における自動要約処理のメイン 動作を表したフローチャートである。
- 【図4】同上、実施形態における図3に示した自動要約 処理の各工程に対応する処理を概念的に表した説明図の 一部である。
- 【図5】同上、実施形態における図3に示した自動要約 処理の各工程に対応する処理を概念的に表した説明図の 他の一部である。
- 【図6】同上、実施形態における図3に示した自動要約 処理の各工程に対応する処理を概念的に表した説明図の 30 163 データ格納部 他の一部である。
- 【図7】同上、実施形態における図3に示した自動要約 処理の各工程に対応する処理を概念的に表した説明図の 他の一部である。
- 【図8】同上、実施形態における図3に示した自動要約 処理の各工程に対応する処理を概念的に表した説明図の 他の一部である。
- 【図9】同上、実施形態における文書ベクトル作成処理 の動作を表したフローチャートである。
- 【図10】同上、実施形態における要約作成処理の動作 40 104 判定手段 を表したフローチャートである。
- 【図11】請求項1に記載した発明のクレーム対応図で ある。
- 【図12】請求項2に記載した発明のクレーム対応図で
- 【図13】請求項4に記載した発明のクレーム対応図の 1 例である。
- 【図14】請求項5に記載した発明のクレーム対応図の 1 例である。
- 【図15】請求項7に記載した発明のクレーム対応図で 50 207 関連付け機能

ある。

- 【図16】請求項8に記載した発明のクレーム対応図で
- 【図17】請求項10に記載した発明のクレーム対応図 の1例である。
- 【図18】請求項11に記載した発明のクレーム対応図 の1例である。
- 【図19】請求項13に記載した発明のクレーム対応図
- 【図20】請求項14に記載した発明のクレーム対応図
 - 【図21】請求項15に記載した発明のクレーム対応図 である。

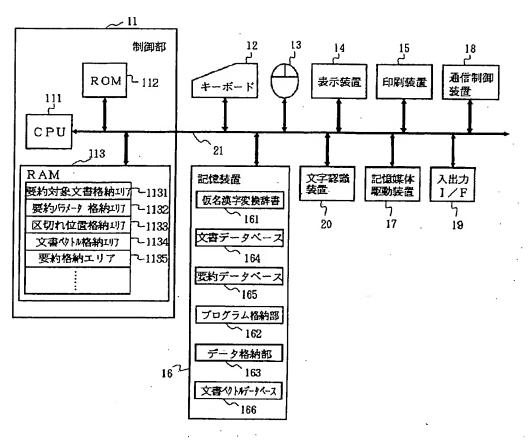
【符号の説明】

- 11 制御部
- 112 ROM
- 113 RAM
- 1131 要約対象文書格納エリア
- 1132 要約パラメータ格納エリア -
- 20 1133 区切れ位置格納エリア
 - 1134 文書ベクトル格納エリア
 - 1135 要約格納エリア
 - 12 キーボード
 - 13 マウス
 - 1 4 表示装置
 - 15 印刷装置
 - 16 記憶装置
 - 161 仮名漢字変換辞書
 - 162 プログラム格納部
 - - 164 文書データベース
 - 165 要約データベース
 - 166 文書ベクトルデータベース
 - 17 記憶媒体駆動装置
 - 18 通信制御装置
 - 19 入出力 I / F
 - 101 文書取得手段
 - 102 文書分割手段
 - 103 類似度算出手段

 - 105 文書ベクトル決定手段
 - 106 要約作成手段
 - 107 関連付け手段
 - 201 文書取得機能
 - 202 文書分割機能
 - 203 類似度算出機能
 - 204 判定機能
 - 205 文書ベクトル決定機能
 - 206 要約作成機能

テキスト文書 HTML文書 JIS文書 他の形式文書

【図1】



【図2】 【図4】

2	文書ベクトルデータベース										文書Aを取得
	文音	キーワードの要素値 f (x)							:		テキスト文 HTML文
			重 要	重要語	重要度		政治				JIS文書 他の形式文
$\cdot [$	٨		2	20	21		_		(A)	文書A	
	В		I	18	19		-				
	С		18	_	_		21				
									l	<i>\bigcup</i>	
						!					•
•		•	•		•	•	•	•	_		who when you have a large or



